Beschleunigung ins Chaos?
Eine systemische Kritik an sektorneutraler KI-Beschleunigung und das X$^{\infty}$-Modell als ethisch-mathematischer Gegenentwurf

Der Auctor
x_to_the_power_of_infinity@protonmail.com
X: @tothepowerofinf
GitHub: Xtothepowerofinfinity

22. April 2025

Zusammenfassung

Dieses Paper kritisiert die Annahmen des „AI Acceleration: A Solution to AI Risk Policy"-Papers, welches argumentiert, dass eine sektorübergreifende Beschleunigung technologischen Fortschritts zur Risikominderung geeignet sei. Wir zeigen, dass diese Annahme insbesondere im Kontext der Künstlichen Intelligenz (KI) aufgrund rekursiver Selbstoptimierung, Rückkopplungsschleifen und chaotischer Übergänge gefährlich verkürzt ist. Unter Rückgriff auf mathematische Modelle, Systemtheorie und ethische Prinzipien, die im X$^{\infty}$-Modell (Accountability-basiertes Steuerungsmodell mit Cap-Logik, Rückkopplungspflicht und auditierbarer Delegation; Projektstatus und Vorabinformationen unter: https://github.com/Xtothepowerofinfinity/Philosophie_der_Verantwortung) verankert sind, argumentieren wir für eine Feedback-basierte, verantwortungsorientierte Steuerung von KI-Entwicklung. Sektorübergreifende Beschleunigung ohne spezifische KI-Risikomodellierung erhöht nachweislich das Risiko einer „wilden Singularität" anstatt es zu senken. Verfügbar unter CC BY-SA 4.0.

Zusammenfassung

[English] This paper critiques the assumptions of the "AI Acceleration: A Solution to AI Risk Policy" paper, which argues that sector-wide acceleration of technological progress is suitable for risk mitigation. We demonstrate that this assumption, particularly in the context of Artificial Intelligence (AI), is dangerously oversimplified due to recursive self-optimization, feedback loops, and chaotic transitions. Drawing on mathematical models, systems theory, and ethical principles embedded in the X$^{\infty}$-Model (an accountability-based governance model with cap logic, feedback obligation, and auditable delegation; project status and preliminary information at: https://github.com/Xtothepowerofinfinity/Philosophie_der_Verantwortung), we advocate for a feedback-based, responsibility-oriented approach to AI development. Sector-wide acceleration without specific AI risk modeling demonstrably increases the risk of a "wild singularity" rather than reducing it. Available under CC BY-SA 4.0.

1 Einleitung

Das Paper „AI Acceleration: A Solution to AI Risk Policy“ (Trammell and Aschenbrenner, 2024) stellt die These auf, dass eine gleichmäßige, sektorübergreifende Beschleunigung des technologischen Fortschritts – insbesondere unter regulatorischer Aufsicht – existenzielle Risiken mindern könnte. Die Autor:innen gehen davon aus, dass eine Verkürzung der riskanten Übergangsphasen („phase compression“) eine Verringerung kumulativer Risiken bewirkt.

Diese Arbeit stellt dem eine systemische, mathematische und ethische Kritik entgegen. Insbesondere im KI-Bereich wirken Beschleunigungsstrategien nicht linear, sondern selbstverstärkend – was die Grundannahmen des Papiers unterläuft. Das X^∞-Modell (in Vorbereitung) liefert hierfür ein theoretisches und ethisch fundiertes Gegenmodell.

2 Mathematische Kritik: Die Unterschlagung von $R_{\mathbf{KI}}(t)$

Das diskutierte Paper betrachtet das Gesamtrisiko als additive Funktion:

$$R_{\text{total}}(t) = R_{\text{sectors}\neq\text{KI}}(t) + R_{\text{KI}}(t). \tag{1}$$

Die Dynamik von $R_{\text{KI}}(t)$ wird dabei entweder als konstant oder als proportional zur allgemeinen Entwicklungsrate S_i angenommen.

Diese Vereinfachung verkennt die eigentliche Risikostruktur im KI-Bereich:

$$R_{\text{KI}}(t) = h(S_{\text{KI}}(t), C(t)), \tag{2}$$

wobei $S_{\text{KI}}(t)$ den Entwicklungsstand und $C(t)$ die Kontrollkapazitäten beschreibt. Bei exponentiellem Wachstum von $S_{\text{KI}}(t)$ und linearem oder verzögertem Wachstum von $C(t)$ dominiert $R_{\text{KI}}(t)$ unweigerlich das Gesamtrisiko:

$$R_{\text{KI}}(t) \sim e^{\lambda t}, \quad \lambda > 0. \tag{3}$$

Dieses Verhalten wird in Bostrom (2014); Yudkowsky (2008); Russell (2019); Tegmark (2017) als zentrales Risikopotenzial von AGI identifiziert und durch das X^∞-Modell explizit adressiert.

3 Selbstverstärkung und Wildtyp-Singularität

Die spezifische Gefahr rekursiver Selbstoptimierung wird durch eine nichtlineare Rückkopplungsdifferentialgleichung beschrieben:

$$\frac{dS_{\text{KI}}}{dt} = k \cdot S_{\text{KI}} + \alpha S_{\text{KI}}^2. \tag{4}$$

Die Lösung dieser Gleichung zeigt ein Blow-up-Verhalten:

$$S_{\mathrm{KI}}(t) \sim \frac{1}{t_0 - t}, \tag{5}$$

was bedeutet, dass $S_{\mathrm{KI}}(t)$ gegen unendlich divergiert, sobald t den kritischen Zeitpunkt t_0 erreicht.

Dieses Verhalten beschreibt nicht nur mathematisch eine Singularität, sondern spiegelt auch die reale Gefahr wider, dass bei fehlender Kontrollkapazität die Dynamik der KI-Entwicklung unkontrollierbar eskaliert. Der Begriff der „wilden Singularität“ bezeichnet dabei eine ungebremste, selbstverstärkende Entwicklung, die weder ethisch legitimiert noch systemisch rückgekoppelt ist.

Das X$^\infty$-Modell fordert daher als ethische und mathematische Mindestbedingung:

$$\frac{dC(t)}{dt} \geq \frac{dS_{\mathrm{KI}}(t)}{dt}, \tag{6}$$

um Stabilität und Kontrollfähigkeit zu gewährleisten.

4 Systemische Rückkopplung als Gegenentwurf

Die Idee, Risiken durch Rückkopplung zu begrenzen, steht im Zentrum des X$^\infty$-Modells. Dabei wird Kontrolle nicht durch zentrale Planung, sondern durch dezentral auditierbare Rückkopplungsmechanismen organisiert, die Verantwortung anhand von Cap-Historie und Wirkung dokumentieren.

Der Kern des Modells besteht in der Überzeugung, dass ethische Legitimation nicht deklarativ, sondern strukturell fundiert sein muss: Wer Verantwortung trägt, muss dies transparent, nachvollziehbar und rückgekoppelt tun. Macht ist kein Selbstzweck, sondern folgt aus getragener Accountability.

> Accountability replaces power. Cap legitimiert Wirkung, nicht Status.

Damit stellt das Modell keine bloße Theorie dar, sondern eine Architektur zur operationalisierbaren Ethik.

5 Ethische Fundamentierung des X$^\infty$-Modells

Die ethische Grundlage des X$^\infty$-Modells unterscheidet sich radikal von utilitaristischen oder pragmatischen Ansätzen der Risikosteuerung. Während viele bestehende Modelle, darunter auch Deweys differenzielle Technologieentwicklung, implizit oder explizit eine Maximierung des Gesamtnutzens (oder eine Minimierung aggregierter Risiken) anstreben, basiert das X$^\infty$-Modell auf einer absolutistischen Ethik des Schutzes der Schwächsten.

Diese Ethik ist nicht Ergebnis einer Güterabwägung, sondern konstituierendes Prinzip der Legitimation selbst. Das bedeutet:

Keine technologische Entwicklung ist legitim, wenn sie die Schwächsten gefährdet — unabhängig davon, wie groß der potenzielle Gesamtnutzen sein mag.

Das Modell positioniert sich damit explizit gegen utilitaristische Bewertungslogiken wie:

$$V_{\text{life}}(t) = f(W(t)), \tag{7}$$

wobei $V_{\text{life}}(t)$ den Wert eines Lebens und $W(t)$ dessen Ressourcenbasis beschreibt. Diese Gleichung, typisch für viele ökonomische Modelle der Risikobewertung, wird im X$^\infty$-Modell verworfen.

Stattdessen gilt:

Wirkung legitimiert. Status nicht. Schutz ist Pflicht.

Accountability wird zur einzigen zulässigen Grundlage von Einflussnahme. Das Cap-System quantifiziert die historisch getragene Verantwortung als Maß für die zulässige Nutzung von Mitteln.

6 Das Cap-System als Steuerungsinstrument

Das Cap-System des X$^\infty$-Modells operationalisiert Verantwortung. Es beschreibt nicht Machtgrenzen, sondern die systemisch legitimierte Fähigkeit, Verantwortung zu tragen. Cap entsteht ausschließlich durch nachgewiesene, getragene Verantwortung — es ist nicht vererbbar, nicht käuflich und nicht delegierbar ohne Rückkopplung.

Die Grundgleichung des Systems lautet:

$$\text{Cap}_{\text{total}} = \text{Cap}_{\text{Solo}} + \text{Cap}_{\text{Team}} \leq \text{Cap}_{\text{Potential}}. \tag{8}$$

Delegation erfolgt nur, wenn sowohl Sender als auch Empfänger ausreichend Cap besitzen. Vertikale Delegation ist nur zulässig bei:

$$\text{Cap}_{\text{Sender}} \geq \text{Cap}_{\text{Threshold}} \quad \text{und} \quad \text{Cap}_{\text{Empfänger}} \geq \text{Cap}_{\text{Delegation-Min}}. \tag{9}$$

Ein Verstoß gegen diese Regel erzeugt systemische Blockade. Das System kennt keine Strafe — aber es kennt Wirkungslosigkeit als automatische Folge von Rückkopplungsverweigerung.

7 Rückkopplung als systemische Ethik

Rückkopplung ersetzt im X$^\infty$-Modell klassische Moral. Nicht Intention, sondern Wirkung entscheidet über Legitimation. Fehlverhalten wird nicht bestraft, sondern rückgeführt und blockiert.

Nicht Moral, sondern Wirkung. Nicht Ich, sondern Dienst. Nicht Chaos, sondern Struktur.

Fehler sind erlaubt, solange sie rückgekoppelt werden. Vermeidung von Rückkopplung dagegen ist systemischer Verrat am Modell.

8 Vergleich mit alternativen Steuerungsansätzen

8.1 Differenzielle Technologieentwicklung (Dewey, 2015) und ihre Limitationen im Kontext exponentieller KI-Dynamiken

Dewey (Dewey, 2015) formuliert mit dem Konzept der *differenziellen Technologieentwicklung* einen pragmatischen Ansatz zur Risikominderung in technologischen Entwicklungspfaden. Die Kernidee besteht darin, Technologien mit einem positiven Sicherheitsprofil (z. B. KI-Alignment-Methoden, robuste Kontrollsysteme) zu priorisieren, während hochriskante Entwicklungslinien (z. B. autonome, nicht kontrollierte AGI) bewusst verzögert werden. Dieses Prinzip basiert auf der Annahme, dass die Geschwindigkeit technologischen Fortschritts ein steuerbarer Parameter sei — und dass Sicherheit durch Priorisierung innerhalb existierender Förder- und Entscheidungssysteme erreichbar bleibt.

Mathematisch lässt sich dieser Ansatz als Priorisierungsproblem formulieren:

$$\min R(t) = \sum_i w_i \cdot R_i(t), \tag{10}$$

wobei $R_i(t)$ die Risikoexposition einzelner Technologien S_i zum Zeitpunkt t und w_i deren gewichtete Priorisierung darstellen. Die Risikominderung wird somit als Aggregatwirkung optimierter Ressourcenzuteilung konzeptualisiert.

Obgleich dieser Ansatz gegenüber einer blinden Beschleunigungsstrategie (Trammell and Aschenbrenner, 2024) zweifellos einen ethischen Fortschritt darstellt, verbleibt er in einer linearen, statischen Betrachtung technologischer Entwicklung. Dewey berücksichtigt weder die exponentielle Selbstverstärkung rekursiver KI-Optimierung noch die inhärenten Rückkopplungseffekte, welche die Dynamik von KI-Systemen fundamental prägen.

8.2 Das X$^\infty$-Modell: Rückkopplung als systemische Pflicht, Ethik als Struktur

Das hier vorgestellte X$^\infty$-Modell setzt genau an dieser konzeptionellen Schwäche an. Es begreift technologische Entwicklung nicht als statische Sequenzierung, sondern als dynamisches, selbstverstärkendes System, dessen Stabilität nur durch *strukturierte Rückkopplungspflicht* gewährleistet werden kann. Zentraler Unterschied zu Dewey ist nicht lediglich das *Wie* der Priorisierung, sondern das *Ob* der Legitimation selbst: Kein Entwicklungspfad ist innerhalb des X$^\infty$-Rahmens legitim, wenn er nicht rückgekoppelt, auditierbar und verantwortungsgetragen ist.

Die mathematische Intuition des Modells fußt auf der expliziten Modellierung von Selbstverstärkung:

$$\frac{dS_{\text{KI}}}{dt} = k \cdot S_{\text{KI}} + \alpha S_{\text{KI}}^2, \tag{11}$$

wobei das Blow-up-Verhalten ($S_{\text{KI}}(t) \sim \frac{1}{t_0 - t}$) nicht nur theoretisches Artefakt, sondern empirisch plausible Dynamik rekursiver KI-Selbstverbesserung darstellt. Das X$^\infty$-Modell definiert als notwendige Bedingung zur Risikobegrenzung, dass die Kontrollmechanismen $C(t)$ mindestens mit der Wachstumsgeschwindigkeit von $S_{\text{KI}}(t)$ Schritt halten müssen:

$$\frac{dC(t)}{dt} \geq \frac{dS_{\text{KI}}(t)}{dt}. \tag{12}$$

Diese Bedingung ist nicht optional, sondern systemethisch verpflichtend. Ihre Nichterfüllung stellt per Definition einen ethischen Verstoß dar.

Das X$^\infty$-Modell integriert darüber hinaus zyklische Fehlanreize (Schweinezyklus, Ezekiel, 1938) und dynamische Interdependenzen über sektorenübergreifende Kopplungen:

$$R_{\text{total}}(t) = R_{\text{sectors} \neq \text{KI}}(t) + R_{\text{KI}}(t), \tag{13}$$

wobei $R_{\text{KI}}(t)$ dominieren kann, sobald Kontrollmechanismen nicht mithalten.

8.3 Ethische Singularität: Die absolute Priorität des Schutzes der Schwächsten

Ein entscheidender Unterschied zwischen Dewey und X$^\infty$ liegt in der ethischen Grundhaltung: Während Deweys Ansatz utilitaristisch bleibt und auf globale Schadensminimierung fokussiert, lehnt das X$^\infty$-Modell jede Form utilitaristischer Wertgewichtung ab. Der Schutz der Schwächsten ist nicht Mittel zum Zweck, sondern ethischer Endpunkt der Systemstruktur selbst. Es gibt keine Rechtfertigung für Beschleunigung, wenn Rückkopplung fehlt. Es gibt kein Argument für Priorisierung, wenn Accountability nicht gegeben ist. Die *Optionslosigkeit* des X$^\infty$-Modells ist keine Dogmatik – sie ist mathematisch, systemtheoretisch und ethisch notwendig.

Das Modell ist daher nicht eine Alternative unter vielen, sondern ein notwendiges Fundament für jede ernstzunehmende KI-Risikosteuerung, die mehr will als Hoffnung: Es strukturiert Pflicht. Es operationalisiert Ethik. Und es immunisiert gegen die systemische Ausrede, dass es „gerade nicht anders ging“.

9 Fazit

Die Prämissen des „AI Acceleration“-Papers (Trammell and Aschenbrenner, 2024) führen nicht zur Risikosenkung, sondern forcieren dynamische Destabilisierung. Das X$^\infty$-Modell bietet einen ethisch fundierten und mathematisch konsistenten Gegenentwurf, der durch Rückkopplung und Verantwortungslogik eine Stabilisierung ermöglicht. Die vollständige Veröffentlichung des X$^\infty$-Modells folgt.

Literatur

Nick Bostrom. *Superintelligence: Paths, Dangers, Strategies*. Oxford University Press, 2014.

Daniel Dewey. Differential Technological Development. Open Philanthropy Project, 2015. https://www.openphilanthropy.org/research/differential-technology-development/.

Mordecai Ezekiel. The Cobweb Theorem. *Quarterly Journal of Economics*, 52(2):255–280, 1938.

Stuart Russell. *Human Compatible: Artificial Intelligence and the Problem of Control*. Viking Press, 2019.

Michael J. Sandel. *The Case Against Perfection: Ethics in the Age of Genetic Engineering*. Harvard University Press, 2007.

Max Tegmark. *Life 3.0: Being Human in the Age of Artificial Intelligence*. Alfred A. Knopf, 2017.

Philip Trammell and Leopold Aschenbrenner. AI Acceleration: A Solution to AI Risk Policy. Global Priorities Institute, GPI Working Paper No. 13-2024. https://globalprioritiesinstitute.org/wp-content/uploads/AI-Acceleration-A-Solution-to-AI-Risk-Policy.pdf.

Eliezer Yudkowsky. Artificial Intelligence as a Positive and Negative Factor in Global Risk. In Nick Bostrom and Milan M. Ćirković (Eds.), *Global Catastrophic Risks*, pp. 308–345. Oxford University Press, 2008.